



UNIVERSAL INTERNATIONAL SCIENTIFIC JOURNAL

Homepage of the Journal <https://universaljournal.uz>

UNIVERSAL INTERNATIONAL
SCIENTIFIC JOURNAL

e-ISSN: [3060-4540 \(online\)](https://universaljournal.uz)

Year: 2026 Issue: 3 Volume: 6

Published: 4.06.2026

<https://universaljournal.uz>



International indexes

GOOGLE SCHOLAR

CROSSREF

ZENODO

RESEARCHGATE

SJIF

INDEX COPERNICUS

RESEARCHBIB

ПРОГНОЗИРОВАНИЕ ДАННЫХ ПОДЗЕМНЫХ ВОДОНОСНЫХ БАССЕЙНОВ С ИСПОЛЬЗОВАНИЕМ МОДЕЛЕЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Дадажонова Зилола Ботиржон кизи, Махмуджанов Сарвар Улугбекович, Нурмуродов
Жавохир Нурмурод угли

¹Ассистент Ташкентский университет информационных технологий имени Мухаммада аль-Хорезми
Начальник отдела научных исследований и трансфера технологий, инкубации и акселерации

²Ташкентский университет информационных технологий имени Мухаммада аль-Хорезми Доцент

³Ташкентский университет информационных технологий имени Мухаммада аль-Хорезми

Uzbekistan

✉ ziloladadajonova@mail.ru s.makhmudjanov@gmail.com nurmurodov1994@gmail.com

Article Info

20 May 2026

Accepted:

27 May 2026

Available Online:

6 June 2026

Copyright © 2025 by author(s) and
Scientific Research Publishing Inc.

This work is licensed under the
Creative Commons Attribution
International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>

Language: Russian

Annotatsiya:

Mazkur maqolada yer osti suv havzalari ma'lumotlarini sun'iy intellekt modellari yordamida bashorat qilish masalalari ko'rib chiqilgan. Tadqiqotda yer osti suvlarining gidrogeologik va gidrodinamik ko'rsatkichlari asosida ma'lumotlarni tahlil qilish hamda ularning kelajakdagi o'zgarishlarini aniqlash usullari o'rganilgan. Sun'iy intellekt modellaridan foydalanish murakkab jarayonlar o'rtasidagi bog'liqliklarni aniqlash va bashorat natijalarining aniqligini oshirish imkonini beradi. Tadqiqot natijalari yer osti suv resurslarini monitoring qilish, ularni samarali boshqarish hamda qaror qabul qilish tizimlarini takomillashtirishda qo'llanilishi mumkin.

Kalit so'zlar:

yer osti suvlari, sun'iy intellekt, bashoratlash, gidrogeologik ma'lumotlar, mashinali o'qitish, monitoring, ma'lumotlar tahlili.

Аннотация:

В данной статье рассмотрены вопросы прогнозирования данных подземных водоносных бассейнов с использованием моделей искусственного интеллекта. В ходе исследования изучены методы анализа данных на основе гидрогеологических и гидродинамических показателей подземных вод, а

также способы определения их будущих изменений. Использование моделей искусственного интеллекта позволяет выявлять взаимосвязи между сложными процессами и повышать точность результатов прогнозирования. Результаты исследования могут быть применены для мониторинга ресурсов подземных вод, их эффективного управления и совершенствования систем поддержки принятия решений.

Ключевые слова:

подземные воды, искусственный интеллект, прогнозирование, гидрогеологические данные, машинное обучение, мониторинг, анализ данных.

Abstract:

This article examines the issues of forecasting groundwater basin data using artificial intelligence models. The study investigates methods for analyzing groundwater data and identifying future changes based on hydrogeological and hydrodynamic indicators. The use of artificial intelligence models makes it possible to identify complex relationships between processes and improve the accuracy of forecasting results. The research findings can be applied in groundwater resource monitoring, effective management of water resources, and the improvement of decision-making systems.

Keywords:

groundwater, artificial intelligence, forecasting, hydrogeological data, machine learning, monitoring, data analysis.

ВВЕДЕНИЕ

В последние годы в мире значительно расширяется применение математических методов, статистических моделей, а также геоинформационных систем в процессах моделирования и прогнозирования водных ресурсов. На международном уровне увеличивается количество научных исследований, посвящённых анализу и прогнозированию водных ресурсов с использованием технологий машинного обучения и глубокого обучения, в частности моделей LSTM, GRU и Transformer.

Вместе с тем, в условиях Узбекистана вопросы цифровой обработки данных подземных минеральных вод и их прогнозирования на основе искусственного

интеллекта изучены недостаточно глубоко.

В большинстве научных исследований по-прежнему преобладают классические гидрогеологические методы анализа и статистические подходы. В связи с этим данная диссертационная тема представляет собой новое научное и практическое направление и направлена на восполнение существующего научного пробела.

АНАЛИЗ ЛИТЕРАТУРЫ И МЕТОДЫ

В последние годы количество научных исследований, посвящённых использованию алгоритмов искусственного интеллекта для анализа и прогнозирования водных ресурсов, значительно увеличилось. В ряде исследований отмечается, что традиционные статистические подходы,

включая регрессионный анализ, авторегрессионные модели и классические методы гидрогеологических расчётов, не способны в полной мере описывать сложные динамические характеристики водных систем. Особенно актуальным применение методов глубокого обучения становится вследствие многофакторности, нелинейности и наличия временных задержек в гидрогеологических системах.

Анализ научной литературы показывает, что для прогнозирования уровня подземных вод и гидрохимических параметров применялись различные методы машинного обучения. В частности, широкое применение получили искусственные нейронные сети (ANN), методы опорных векторов (SVM), Random Forest, а также модели на основе рекуррентных нейронных сетей (RNN). Однако традиционные модели RNN сталкиваются с проблемой исчезающего градиента (*vanishing gradient*) при обработке долгосрочных зависимостей.

Для решения данной проблемы были разработаны архитектуры Long Short-Term Memory (LSTM) и Gated Recurrent Unit (GRU). Модель LSTM позволяет сохранять долгосрочные зависимости посредством специальных ячеек памяти и механизмов управления (*gates*). В свою очередь, модель GRU обладает более упрощённой архитектурой, что позволяет повысить

скорость вычислений за счёт меньшего количества параметров.

В современных исследованиях также активно используются модели, основанные на архитектуре Transformer. Transformer-модель благодаря механизму *self-attention* позволяет выявлять долгосрочные зависимости между временными рядами. Данный подход продемонстрировал высокую точность прогнозирования в задачах метеорологического прогнозирования, экологического мониторинга и моделирования гидрологических систем.

В рамках данного исследования для анализа данных подземных водных бассейнов и прогнозирования их состояния до 2050 года были использованы модели Transformer, LSTM и GRU. В качестве исходных данных использовались гидрогеологические и гидродинамические показатели, включая уровень подземных вод, расход воды, показатели минерализации воды, а также гидрохимические параметры.

На этапе подготовки данных выполнялись процедуры заполнения пропущенных значений, уменьшения шумов и нормализации данных. После этого данные были разделены на обучающую (*training*), валидационную (*validation*) и тестовую (*test*) выборки.

В модели Transformer анализ взаимосвязей между данными выполнялся на основе механизма self-attention, тогда как в моделях LSTM и GRU осуществлялось изучение последовательных временных зависимостей. Для оценки эффективности моделей использовались показатели Training Loss, Validation Loss, Test Loss, Accuracy и RMSE.

На основе полученных результатов была проведена сравнительная оценка эффективности различных моделей, а также проанализированы возможности выявления долгосрочных тенденций изменения параметров в системе подземных вод. Предлагаемый подход может служить научно-практической основой для управления ресурсами подземных вод, автоматизации систем мониторинга и совершенствования процессов принятия решений.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Процесс прогнозирования уровня подземных вод представляет собой задачу многомерных временных рядов, в которой гидродинамические, метеорологические и данные дистанционного зондирования анализируются в интегрированном виде. Модели Transformer обладают значительными преимуществами при моделировании именно таких сложных

систем, характеризующихся множеством параметров и наличием долгосрочных взаимосвязей.

Поскольку система подземных вод представляет собой среду с длительной памятью, множеством управляющих факторов и склонностью к смене режимов, использование Transformer-моделей для устойчивого прогнозирования уровня подземных вод и гидрохимических показателей до 2050 года обеспечивает существенные научно-практические преимущества. Уникальный механизм внимания (attention) позволяет Transformer-моделям явно моделировать долгосрочные временные зависимости без рекуррентных задержек: каждая временная точка непосредственно взаимодействует со всеми остальными точками, благодаря чему такие закономерности, как сезонные циклы, накопленное в течение многих лет антропогенное воздействие, отложенные цепочки «осадки–сток–уровень–химический состав», а также чередование засушливых и влажных периодов, объединяются в рамках единой модели.

Основной механизм внимания описывается следующим выражением:

$$\text{Attention} \\ (Q,K,V)=\text{softmax}((QK^T)/\sqrt{d_k})V \\ (1)$$

Здесь оценивается степень соответствия между ключами (keys), запросами (queries) и значениями (values), при этом модель присваивает более высокие веса наиболее значимым временным интервалам. В результате Transformer-модели способны формировать долгосрочные многократные прогнозы одновременно как для уровня подземных

вод, так и для гидрохимических параметров на основе многомерных временных рядов, включающих метеорологические входные данные, журналы ирригации и откачки воды, показатели речного стока, потенциальное испарение, индексы дистанционного зондирования и лабораторные профили ионов.

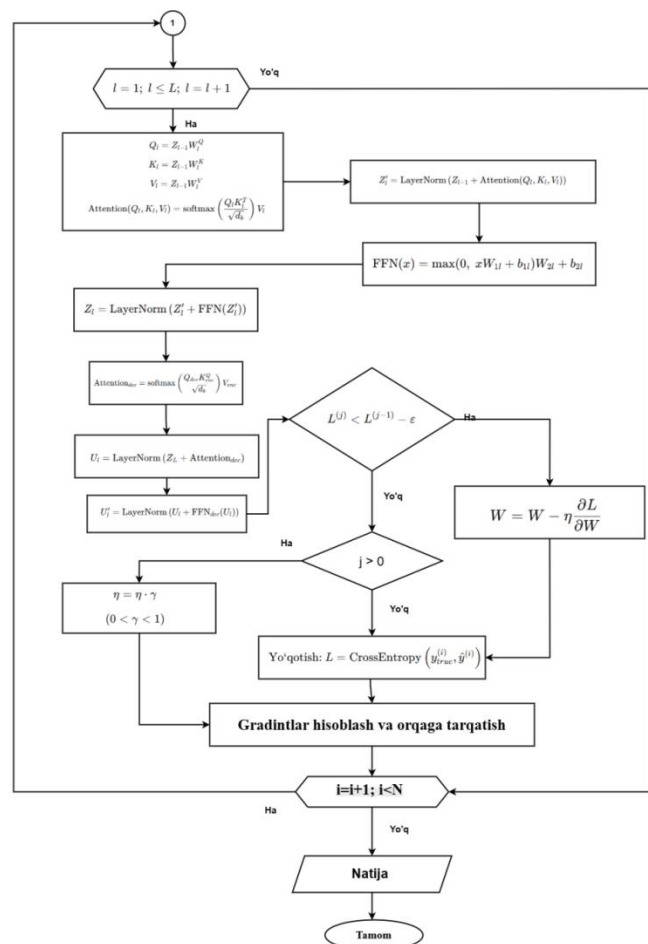
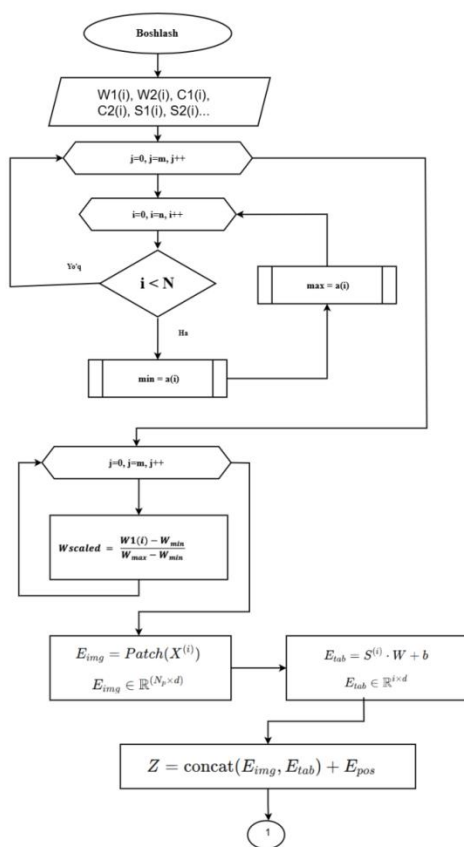


Рисунок 1. Алгоритм прогнозирования состояния гидрогеологических данных до 2050 года с использованием мультимодальной модели Transformer

В представленной блок-схеме (Рисунок 1) процесс прогнозирования будущего состояния гидрогеологических данных

осуществляется с использованием модели на основе Transformer. После выполнения вычислительных этапов полученные

результаты представляются в табличной форме. В данной таблице отражены основные показатели эффективности, полученные в результате применения модели Transformer, включая потери на обучающей выборке (training loss) и потери на валидационной выборке (validation loss), а также точность обучения (training accuracy)

и точность валидации (validation accuracy). Кроме того, для заключительного этапа оценки отдельно рассчитываются значения потерь на тестовой выборке (test loss) и точности на тестовой выборке (test accuracy), которые формируются для проведения сравнительного анализа.

Таблица 1. Результаты определения потерь и точности обучения и валидации с использованием модели GRU

Epoch	Train Loss	Validation Loss	Train Accuracy	Validation Accuracy
[10/20]	0.4766	0.3907	0.5234	0.6093
[20/20]	0.0574	0.0665	0.9426	0.9335
	Final Test Loss	0.0573	Test Accuracy	0.9427

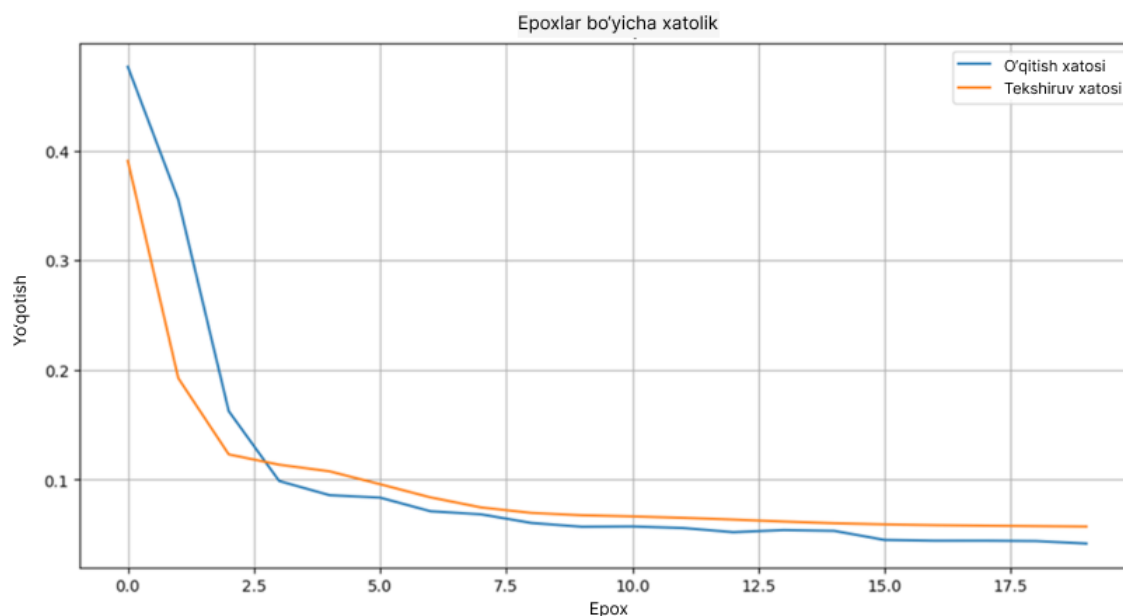


Рисунок 2. Значения функции потерь по эпохам обучения

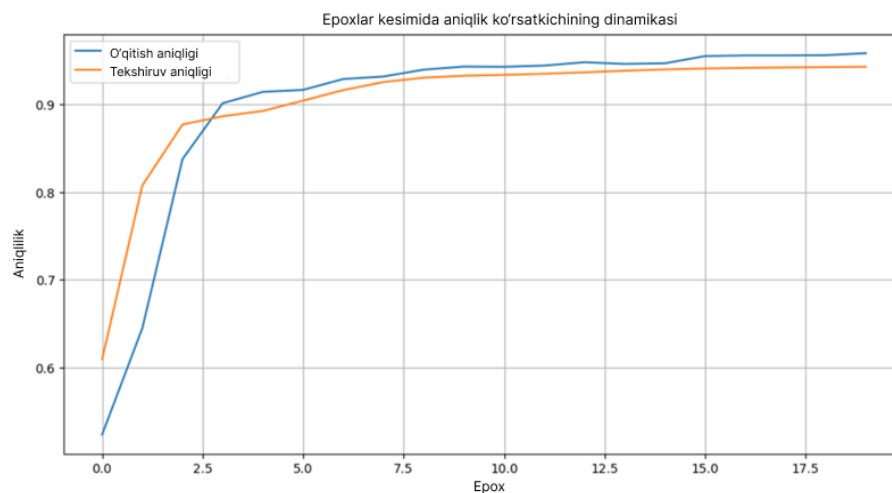


Рисунок 3. Динамика показателей точности по эпохам обучения

В системах подземных вод динамика процессов является весьма сложной вследствие взаимодействия сезонных циклов, задержанных причинно-следственных связей и факторов антропогенного управления. Поэтому многомерная регрессионная модель на основе сетей Long Short-Term Memory (LSTM) играет важную роль в обеспечении надёжного прогнозирования уровня подземных вод и гидрохимических показателей до 2050 года. Механизм шлюзов (gate mechanism) в LSTM обеспечивает сохранение долговременной временной памяти и позволяет выявлять накопительные эффекты в цепочке «осадки – сток – уровень подземных вод – гидрохимические показатели» без деградации рекуррентных связей. Кроме того, структура многовыходной регрессии позволяет одновременно оценивать несколько параметров, таких как уровень подземных

вод, электрическая проводимость (EC/TDS), концентрация хлоридов, концентрация сульфатов, концентрация нитратов, жёсткость воды и коэффициент адсорбции натрия (SAR), используя общее скрытое представление данных.

С математической точки зрения, на временном шаге (t) входной вектор используется для обновления состояния ячейки LSTM и скрытого состояния, после чего формируется многомерный выходной результат следующим образом:

$$\hat{y}_t = Wh_t + b \quad (2)$$

Здесь представляет собой объединённый вектор, содержащий все гидрохимические параметры и значения уровня подземных вод. Функция потерь естественным образом принимает многокритериальную форму и, например, может быть взвешена в соответствии с относительной значимостью параметров следующим образом:

$$\mathcal{L} = \sum_{j=1}^m \alpha_j \text{RMSE}(y^{(j)}, \hat{y}^{(j)}) \quad (3)$$

где обозначает весовой коэффициент, назначаемый в соответствии со значимостью (j)-го параметра. Кроме того, при необходимости определения интервалов неопределённости могут использоваться квантильные функции потерь для построения интервалов прогнозирования, соответствующих 5-му, 50-му и 95-му процентилям.

Данная архитектура обладает двумя существенными преимуществами. С одной

стороны, она позволяет выявлять скрытые ковариационные структуры между несколькими параметрами посредством общего представления памяти. С другой стороны, даже при ограниченном количестве гидрохимических наблюдений модель способна эффективно переносить полезную информацию из сигналов уровня подземных вод, что способствует повышению способности к обобщению и улучшению стабильности прогнозируемых результатов.

Таблица 2. Результаты определения потерь и точности обучения и валидации с использованием модели GRU

Epoch	Train Loss	Validation Loss	Train Accuracy	Validation Accuracy
[1/100]	0.7304	0.6799	14.54%	17.55%
[11/100]	0.4729	0.4269	31.24%	34.66%
[21/100]	0.1249	0.0912	64.65%	69.81%
[31/100]	0.0465	0.0434	78.45%	79.16%
[41/100]	0.0026	0.0059	94.90%	92.35%
[51/100]	0.0062	0.0062	92.12%	92.11%
[61/100]	0.0018	0.0029	95.72%	94.64%
[71/100]	0.0005	0.0017	97.66%	95.88%
[81/100]	0.0006	0.0016	97.57%	96.02%
[91/100]	0.0004	0.0013	97.99%	96.40%
	Final Test Loss	0.0012	Test Accuracy	96.53%

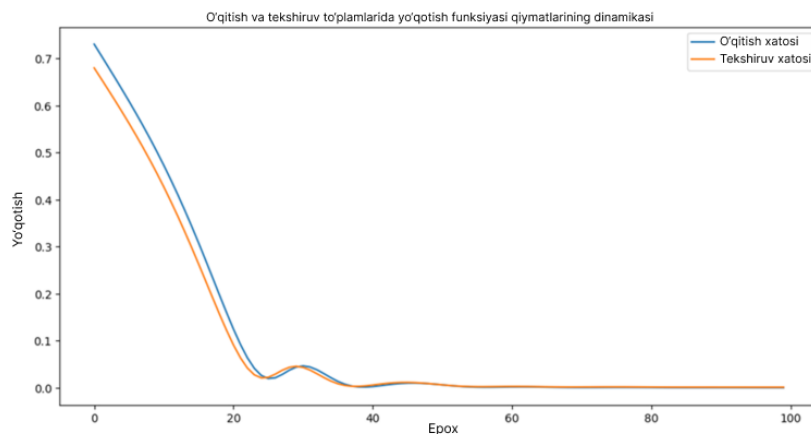


Рисунок 4. Значения функции потерь по эпохам обучения

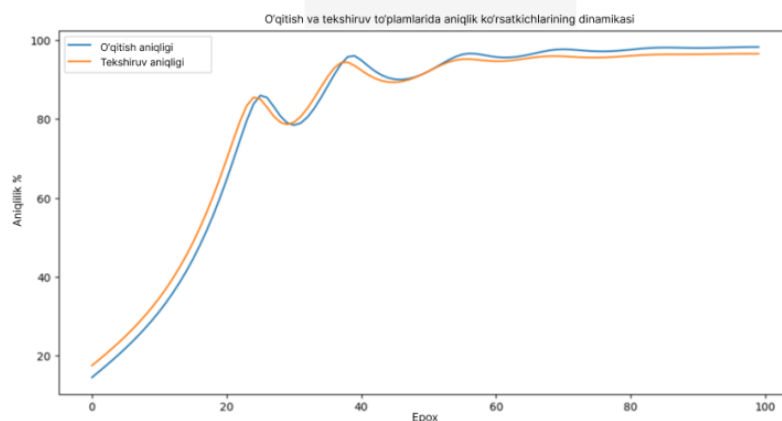


Рисунок 5. Динамика показателей точности на обучающей и валидационной выборках

Таблица 3. Прогнозируемые значения (w1), (w2), (C1) и (C2) за период 2022–2049 гг. с использованием многомерной линейной регрессии на основе LSTM

	W1	W2	C1	C2
2022	9.859212	4.783733	0.205519	1.059987
2023	9.859728	4.783960	0.205528	1.060058
2024	9.860145	4.784132	0.205535	1.060126
2025	9.860481	4.784272	0.205540	1.060182
2026	9.860762	4.784389	0.205545	1.060229
2027	9.860994	4.784489	0.205549	1.060269
2028	9.861145	4.784552	0.205551	1.060295
2029	9.861266	4.784603	0.205553	1.060315
2030	9.861362	4.784643	0.205555	1.060331
2031	9.861437	4.784675	0.205556	1.060344
2032	9.861494	4.784698	0.205557	1.060354
2033	9.861537	4.784717	0.205558	1.060361
2034	9.861570	4.784731	0.205559	1.060367
2035	9.861596	4.784741	0.205559	1.060371
2036	9.861616	4.784750	0.205559	1.060374
2037	9.861631	4.784757	0.205560	1.060377
2038	9.861644	4.784761	0.205560	1.060379
2039	9.861652	4.784765	0.205560	1.060380
2040	9.861659	4.784768	0.205560	1.060382
2041	9.861665	4.784770	0.205560	1.060383
2042	9.861669	4.784772	0.205560	1.060383
2043	9.861672	4.784774	0.205560	1.060384
2044	9.861674	4.784775	0.205560	1.060384
2045	9.861676	4.784776	0.205560	1.060385
2046	9.861678	4.784776	0.205560	1.060385
2047	9.861679	4.784777	0.205560	1.060385
2048	9.861680	4.784777	0.205560	1.060385
2049	9.861681	4.784777	0.205560	1.060385




Рисунок 6. График изменения ключевых параметров по годам

В системах подземных вод уровень подземных вод, расход и гидрохимические показатели изменяются одновременно под воздействием сезонных колебаний, задержанных причинно-следственных связей и факторов антропогенного управления. Поэтому для обеспечения надёжного прогнозирования до 2050 года необходим подход, который является компактным, устойчивым и способен одновременно моделировать несколько переменных. Многомерная регрессия на основе архитектуры Gated Recurrent Unit (GRU) особенно хорошо подходит для решения данной задачи. Благодаря механизмам обновляющего шлюза (z_t) и сбрасывающего шлюза (r_t) модель GRU сохраняет важные временные закономерности и эффективно отфильтровывает избыточный шум. В результате как долгосрочные зависимости,

так и краткосрочные динамические изменения могут быть эффективно представлены в рамках единой нейронной архитектуры. Основные уравнения обновления GRU могут быть представлены следующим образом:

$$\begin{aligned} \tilde{h}_t &= \tanh(Wx_t + r_t \odot Uh_{t-1}) \text{ va } h_t \\ &= (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \end{aligned}$$

где полученное скрытое состояние далее используется в рамках многовыходной регрессионной модели:

$$\hat{y}_t = Wh_t + b$$

Данная формулировка обеспечивает возможность одновременного прогнозирования нескольких показателей, включая уровень подземных вод, электрическую проводимость (EC/TDS), концентрацию хлоридов Cl^- , концентрацию сульфатов SO_4^{2-} , концентрацию нитратов NO_3^- , жёсткость воды и коэффициент адсорбции натрия (SAR).

Кроме того, данная архитектура эффективно переносит ценную информацию из сигналов уровня подземных ковариационные взаимосвязи между вод и метеорологических данных, что параметрами посредством общего способствует повышению способности к представления памяти. Даже в случаях, обобщению и улучшению устойчивости когда гидрохимические наблюдения прогнозирования [25]. являются ограниченными, модель способна

Таблица 4. Результаты определения потерь и точности обучения и валидации с использованием модели GRU

Epoch	Train Loss	Val Loss	Train Acc	Val Acc
[1/100]	0.9818	0.9042	0.91%	4.91%
[11/100]	0.5516	0.4958	25.73%	29.59%
[21/100]	0.1358	0.1065	63.15%	67.36%
[31/100]	0.0437	0.0474	79.10%	78.23%
[41/100]	0.0035	0.0096	94.08%	90.19%
[51/100]	0.0088	0.0131	90.60%	88.56%
[61/100]	0.0021	0.0068	95.43%	91.72%
[71/100]	0.0019	0.0062	95.59%	92.10%
[81/100]	0.0017	0.0062	95.89%	92.15%
[91/100]	0.0013	0.0054	96.39%	92.62%
	Final Test Loss	0.0052	Test Accuracy	92.81%

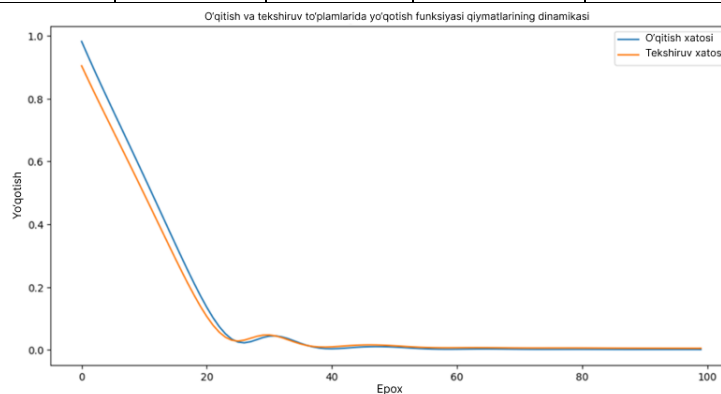


Рисунок 7. Значения функции потерь по эпохам обучения

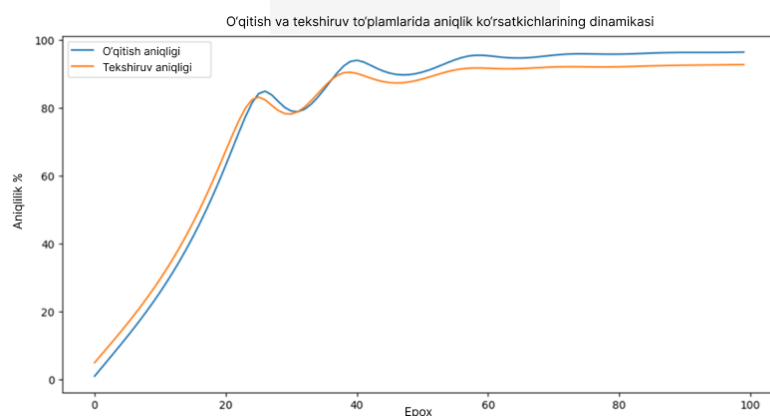


Рисунок 8. Точность по эпохам обучения

Таблица 5. Прогнозируемые значения (w1), (w2), (C1) и (C2) за период 2022–2049 гг. с использованием многомерной линейной регрессии на основе GRU

Year	W1	W2	C1	C2
2022	9,868707	4,785631	0,20559	1,061334
2023	9,870677	4,786582	0,205626	1,061749
2024	9,872688	4,787462	0,20566	1,06212
2025	9,874619	4,788264	0,205692	1,062461
2026	9,876425	4,788986	0,205721	1,062775
2027	9,878079	4,789631	0,205748	1,063061
2028	9,879243	4,790112	0,205767	1,063269
2029	9,880252	4,790524	0,205783	1,063447
2030	9,881113	4,790872	0,205797	1,063599
2031	9,881838	4,791164	0,205809	1,063727
2032	9,88244	4,791407	0,205819	1,063833
2033	9,882936	4,791608	0,205827	1,06392
2034	9,883352	4,791777	0,205834	1,063994
2035	9,883699	4,791917	0,205839	1,064055
2036	9,883989	4,792035	0,205844	1,064106
2037	9,88423	4,792132	0,205848	1,064149
2038	9,884431	4,792213	0,205851	1,064184
2039	9,884598	4,792281	0,205854	1,064214
2040	9,884737	4,792337	0,205856	1,064238
2041	9,884852	4,792384	0,205858	1,064258

2042	9,88495	4,792424	0,205859	1,064276
2043	9,88503	4,792456	0,205861	1,06429
2044	9,885097	4,792483	0,205862	1,064301
2045	9,885153	4,792506	0,205863	1,064311
2046	9,885199	4,792524	0,205863	1,064319
2047	9,885238	4,79254	0,205864	1,064326
2048	9,88527	4,792553	0,205865	1,064332
2049	9,885297	4,792564	0,205865	1,064337

В таблице 5:

W1 – объём притока воды

W2 – объём оттока воды

C1 – минерализация приточной воды

C2 – минерализация отточной воды

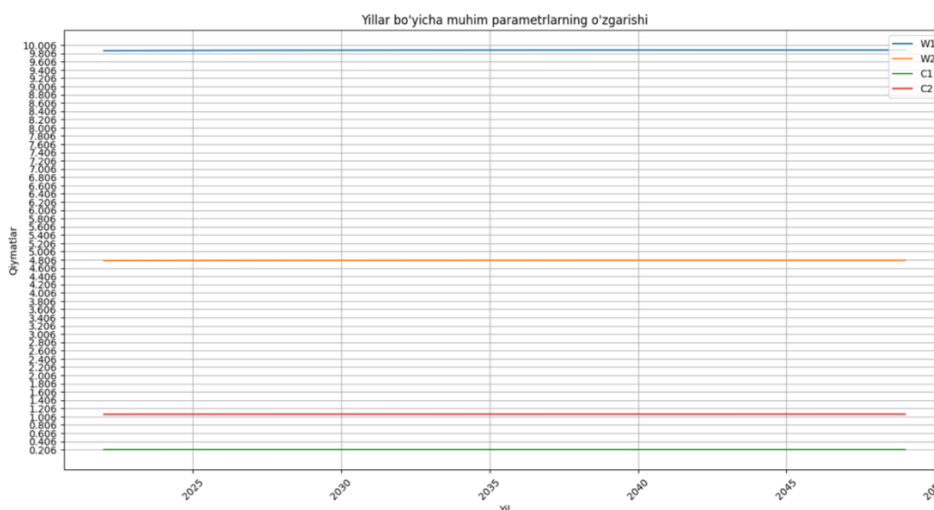


Рисунок 9. График изменения ключевых параметров по годам

Заключение.

Результаты исследования показали, что использование моделей искусственного интеллекта обладает высокой эффективностью при анализе данных подземных водных бассейнов и определении их будущего состояния. Алгоритмы искусственного интеллекта позволяют выявлять сложные взаимосвязи между гидрогеологическими и гидродинамическими показателями, а также обеспечивают возможность обработки больших объёмов данных. Кроме того, данный подход способствует предварительной оценке тенденций изменения подземных вод, автоматизации процессов мониторинга и

повышению точности результатов решений. В дальнейшем целесообразным прогнозированием. Полученные результаты представляется совместное применение исследования могут быть использованы для различных моделей искусственного эффективного управления ресурсами интеллекта, а также интеграция данных из подземных вод, предотвращения нескольких источников с целью экологических проблем и дальнейшего повышения надёжности совершенствования систем принятия результатов прогнозирования.

СПИСОК ЛИТЕРАТУРЫ

- [1]. Haykin S. *Neural Networks and Learning Machines*. — 3rd ed. — New York: Pearson Education, 2009. — pp. 1–936.
- [2]. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. — Cambridge: MIT Press, 2016. — pp. 1–775.
- [3]. Bishop C.M. *Pattern Recognition and Machine Learning*. — New York: Springer, 2006. — pp. 1–738.
- [4]. Russell S., Norvig P. *Artificial Intelligence: A Modern Approach*. — 4th ed. — Pearson Education, 2021. — pp. 1–1168.
- [5]. Géron A. *Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow*. — Sebastopol: O'Reilly Media, 2022. — pp. 1–851.
- [6]. Chollet F. *Deep Learning with Python*. — New York: Manning Publications, 2021. — pp. 1–504.
- [7]. Han J., Kamber M., Pei J. *Data Mining: Concepts and Techniques*. — Waltham: Morgan Kaufmann, 2011. — pp. 1–703.
- [8]. Z.B. Dadajonova, B.D. Abdullaev, N. Zaynidinov, B.B. Akbaraliyev, B.R. Nasibov. Intellectual processing of hydrogeological data (using the example of groundwater) // *British Journal of Global Ecology and Sustainable Development*. — 2024. — Vol. 32. — pp. 1–8.
- [9]. Dadajonova Z.B., Abdullayev B.D., Nasibov B.R., Dadajonov B.B. Monitoring of changes in groundwater quality in irrigated lands of Kashkadarya region // *Bulletin of the University of Geological Sciences*. — 2024. — No. 2. — pp. 1–8.
- [10]. Dadajonova Z.B., Nurmurodov J.N. Classification of deposits with underground resources using artificial intelligence technologies // *Al-Farg‘oniy avlodlari electronic scientific journal*. — 2025. — Vol. 1. — Issue 2.
- [11]. Dadajonova Z.B. Predicting groundwater level changes using an artificial intelligence model // *Scientific article*. — 2026.
- [12]. Zaynidinov H.N., Qobilov S.Sh. A two-dimensional hydrogeological data modeling program based on a spline model independent of nodes. — 2024.
- [13]. Aggarwal C.C. *Neural Networks and Deep Learning*. — Cham: Springer, 2018. — pp. 1–497.
- [14]. Murphy K.P. *Machine Learning: A Probabilistic Perspective*. — Cambridge: MIT Press, 2012. — pp. 1–1067.
- [15]. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning*. — New York: Springer, 2009. — pp. 1–745.
- [16]. Maier H.R., Jain A., Dandy G.C., Sudheer K.P. Methods used for the development of neural networks for the prediction of water resource variables // *Environmental Modelling & Software*. — 2010. — Vol. 25. — No. 8. — pp. 891–909.
- [17]. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. *Artificial Neural*

- Networks in Hydrology // Journal of Hydrologic Engineering. — 2000. — Vol. 5. — No. 2. — pp. 115–123.
- [18]. Kratzert F., Klotz D., Brenner C., Schulz K., Herrnegger M. Rainfall-runoff modelling using Long Short-Term Memory networks // Hydrology and Earth System Sciences. — 2018. — Vol. 22. — pp. 6005–6022.
- [19]. Shalev-Shwartz S., Ben-David S. Understanding Machine Learning: From Theory to Algorithms. — Cambridge: Cambridge University Press, 2014. — pp. 1–410.
- [20]. Abbot M.B., Refsgaard J.C. Distributed Hydrological Modelling. — Dordrecht: Springer, 1996. — pp. 1–336.
- [21]. Ian H.W., Eibe F., Hall M.A. Data Mining: Practical Machine Learning Tools and Techniques. — Burlington: Morgan Kaufmann, 2016. — pp. 1–654.
- [22]. Kelleher J.D., Tierney B. Data Science. — Cambridge: MIT Press, 2018. — pp. 1–280.
- [23]. LeCun Y., Bengio Y., Hinton G. Deep Learning // Nature. — 2015. — Vol. 521. — pp. 436–444.
- [24]. Schmidhuber J. Deep Learning in Neural Networks: An Overview // Neural Networks. — 2015. — Vol. 61. — pp. 85–117.
- [25]. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. — 1997. — Vol. 9. — No. 8. — pp. 1735–1780.